

SVEUČILIŠTE U ZAGREBU  
**FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA**

ZAVRŠNI RAD br. 3741

# **Alat za poravnanje genoma**

Petar Žuljević

Zagreb, lipanj 2014.

*Umjesto ove stranice umetnite izvornik Vašeg rada.*

*Da bi ste uklonili ovu stranicu obrišite naredbu \izvornik.*

*Zahvaljujem mentoru Mili na uloženom trudu i vremenu.*

# SADRŽAJ

<b>Popis slika</b>	<b>vi</b>
<b>Popis tablica</b>	<b>vii</b>
<b>1. Uvod</b>	<b>1</b>
<b>2. Poravnanje genetskih sljedova</b>	<b>2</b>
2.1. Uvod u terminologiju . . . . .	3
2.2. Popularni alati . . . . .	3
2.2.1. MUMmer . . . . .	3
2.2.2. BLASTZ . . . . .	5
2.2.3. LASTZ . . . . .	5
<b>3. Podaci</b>	<b>7</b>
<b>4. Metode</b>	<b>8</b>
4.1. Konstrukcija SA i LCP polja . . . . .	9
4.2. Generiranje MUMova . . . . .	10
4.2.1. Pronalazak MUMova . . . . .	10
4.2.2. Filtriranje MUMova . . . . .	12
4.2.3. Generiranje listi LCP i SA polja za netaknute regije . . . . .	13
4.3. Smith-Waterman . . . . .	14
<b>5. Implementacija</b>	<b>15</b>
5.1. Arhitektura sustava . . . . .	16
<b>6. Rezultati</b>	<b>18</b>
6.1. Ispitni skup . . . . .	18
6.2. Usporedba s alatom MUMmer . . . . .	20
6.2.1. Poravnanje kromosoma X Miš (173.9MB) / Čovjek (157.9MB):	21

**7. Zaključak 22**

**Literatura 23**

# POPIS SLIKA

2.1. Tijek procesa poravnavanja kod MUMmera 1.0 . . . . .	4
4.1. Primjena algoritma LIS . . . . .	12
4.2. Netaknute regije za koje je potrebno kreirati zasebna LCP i SA polja .	13
4.3. Područja za poravnanje Smith-Watermanom . . . . .	14
5.1. Dijagram toka opisanog programa . . . . .	15
5.2. Arhitektura sustava . . . . .	17
6.1. Miš/Čovjek - 18. kromosom - kritična duljina 80 . . . . .	18
6.2. Miš/Čovjek - 18. kromosom - kritična duljina 120 . . . . .	19
6.3. Miš/Čovjek - 18. kromosom - rezultati s Ensembl poslužitelja . . . .	19
6.4. Usporedba: program opisan u radu (lijeva slika) - MUMmer (desna slika) za test primjer Hpylori . . . . .	20
6.5. Usporedba s MUMmerom - chrX - program opisan u radu . . . . .	21
6.6. Usporedba s MUMmerom - chrX - MUMmer . . . . .	21

# POPIS TABLICA

2.1. Primjer jednostavnog poravnanja . . . . .	2
3.1. Značenje znakova u genetskim sljedovima . . . . .	7
4.1. Sufiksno i LCP polje za niz "banana\$" . . . . .	9
6.1. Konstrukcija SA i LCP polja . . . . .	20
6.2. Iterativni pronalazak MUMova . . . . .	20

# 1. Uvod

Bioinformatika je multidisciplinarna grana znanosti koja iziskuje potrebu za korištenjem suvremenih računalnih alata radi efikasne obrade brojnih podataka koji su izdvojeni prilikom bioloških istraživanja. Jedan od problema koji se javlja u bioinformatici naziva se poravnanje genetskih sljedova.

Poravnanje genetskih sljedova još uvijek je problem koji nije u potpunosti riješen. Naime, radi se o usporedbi dvaju genetskih nizova čija se duljina mjeri u nekoliko stotina milijuna pa čak i milijardi dušičnih baza. Upravo zbog tako velike količine podataka potrebno je razviti algoritme i strukture podataka kojima će se moći u razumnom vremenu i uz ograničena računalna sredstva obaviti poravnanje. Sljedovi su prikazani kao nizovi znakova abecede koji označavaju dušične baze (A,C,T,G).

Cilj poravnjanja je pronalazak sličnih ili identičnih regija u genomima koje bi mogle upućivati na genetsku sličnost, svojevrsne mutacije koje su se dogodile ili pak ukazivati na neke bitne funkcionalnosti zastupljene u kodirajućim regijama genoma.

Postojeća rješenja zasnivaju se na heuristikama koje obavljaju poravnanja koristeći različite metode. Trenutno najpopularniji alati su MUMmer (Kurtz et al., 2004), BLASTZ (Schwartz et al., 2003) i LASTZ (Harris, 2007).

U ovom radu obrađena je problematika poravnjanja dvaju genetskih sljedova te je opisan alat koji obavlja tu funkciju. Također su prikazani i rezultati poravnjanja nad kromosomima čovjeka i miša.

## 2. Poravnanje genetskih sljedova

Poravnanje je postupak pronašlaska međusobne sličnosti dvaju ili više nizova. Za zadana dva genetska niza sastavljenih od znakova abecede (A, C, T, G) možemo konstruirati poravnanje tako da umetnemo praznine (oznaka '-') na određena mesta tako da zadani nizovi postanu iste duljine. Znakovi koji nisu praznine predstavljaju poklapanja ili supstitucije. U genetskim nizovima koriste se oznake A, C, T i G jer su tim slovima određene dušične baze

Za rad navedenih algoritama potrebno je definirati parametre koji će se koristiti pri poravnanju. Parametri određuju cijenu umetanja praznine te cijene supstitucija, a pri tome se koriste unaprijed određene supstitucijske matrice.. Supstitucijske matrice dobivene su empirijskim metodama u biološkim istraživanjima te na svojevrstan način opisuju vjerojatnosti zamjene jedne dušične baze s drugom.

Primjerice ako su zadana dva genetska slijeda „ACTTCCAGA“ i „AGTTCCG-GAGG“, poravnanje bi moglo izgledati kao u tablici 2.1 uz cijene umetanja praznine -1, cijenu supstitucije 0 te cijenu poklapanja 1. Ukupna ocjena sličnosti može se reprezentirati sumom cijena izvršenih supstitucija, poklapanja i umetnutih praznina što bi u prikazanom jednostavnom prikazanom slučaju iznosilo 5.

**Tablica 2.1:** Primjer jednostavnog poravnanja

Niz1	A	C	T	T	C	C	-	-	A	G	A
Niz2	A	G	T	T	C	C	G	G	A	G	G
Cijena	1	0	1	1	1	1	-1	-1	1	1	0

Poravnanje navedeno u tablici 2.1 nije jedino moguće rješenje, naime postoji velik broj poravnaja, ali su interesantna samo ona koja imaju najveće ocjene. Pri tome nije moguće koristiti egzaktne algoritme koji će dati optimalno rješenje jer je vrijeme njihovog izvršavanja neprihvatljivo te se stoga koriste heuristike koje će relativno brzo doći do dovoljno dobrih rješenja.

## 2.1. Uvod u terminologiju

U ovom odjeljku navedeni su izrazi i njihove definicije koje će se koristiti u nastavku rada.

**MUM** (*engl. Maximal unique match*) - najdulji podudarajući podniz koji se pojavljuje točno jednom u oba ulazna niza.

**MEM** (*engl. Maximal exact match*) - najdulji podudarajući podnizovi koji se pojavljuju više puta u oba ulazna niza.

**Kritična duljina** - Broj znakova u kojima se MUMovi ili MEMovi moraju podudarati da bi bili uzeti u razmatranje.

**Netaknute regije** - Područja na kojima nisu pronađeni MUMovi niti MEMovi.

**MUMovi šuma** (*engl. Noisy MUMs*) - MUMovi koji su rezultat čiste slučajnosti, javljaju se ako se generiraju MUMovi s nedovoljno velikim parametrom kritične duljine.

**Reverzni komplement** - Niz koji dobijemo kada ga obrnemo i svaku dušičnu bazu zamijenimo s njenom komplementarnom bazom.

**Lokalno poravnjanje** - Poravnanje u kojem pronalazimo dijelove nizova koji su "najsličniji", odnosno najviše se podudaraju.

**Globalno poravnjanje** - Poravnanje prilikom kojeg koristimo sva slova oba niza

## 2.2. Popularni alati

Poznati su algoritmi za optimalno lokalno i globalno poravnjanje koji se zasnivaju na dinamičkom programiranju (Smith-Waterman, Needleman-Wunsch), međutim oni nisu efikasni za poravnjanje nizova čije su duljine većeg reda veličine zbog kvadratne vremenske složenosti u kojoj se izvršavaju. Zbog toga je potrebno pronaći druge načine za obavljanje poravnanja. Danas su najpopularniji alati koji se zasnivaju na heurističkom pristupu poput alata MUMmer (Kurtz et al., 2004), BLASTZ (Schwartz et al., 2003) i LASTZ (Harris, 2007).

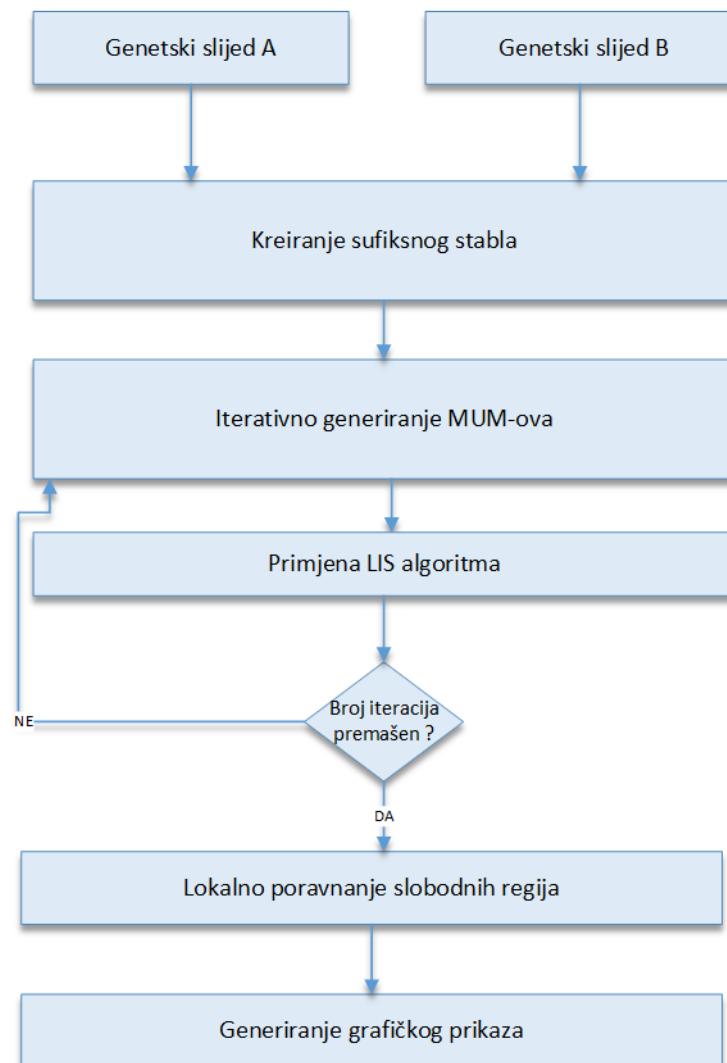
### 2.2.1. MUMmer

MUMmer (Kurtz et al., 2004) je jedan od najbržih alata za poravnanje čitavih genoma. Zadnja inačica je MUMmer 3.0, a zasniva se na izgradnji strukture podataka koja se zove sufiksno stablo.

Rad MUMmera započinje pronalaskom jedinstvenih poklapajućih regija koje se

točno jednom pojavljuju u oba zadana genetska slijeda te se poklapaju u barem K dušičnih baza. Navedena poklapanja nazivaju se MUM-ovi (engl. Maximal Unique Match). Parametar K može se utvrditi i eksperimentalno te je bitno da je dobro određen jer nisu poklapanja svih duljina jednak značajna i vjerojatna. Sufiksno stablo omogućuje u linearnoj vremenskoj složenosti određivanje navedenih poklapanja, ali loša strana je poveća potrošnja memorije za njegovo kreiranje.

Nakon pronaleta MUM-ova postupak se ponavlja na područjima između identificiranih MUM-ova kroz zadani broj iteracija. Zatim se vrši proces filtriranja MUM-ova pomoću LIS algoritma i u konačnici se izvršava proces lokalnog poravnjanja regija koje su između MUM-ova. Dakle, rad alata MUMmer se može podijeliti u tri faze: pronađak poklapanja, grupiranje i proces lokalnog poravnavanja. Inačice alata MUMmer razlikuju se u fazi pronaleta MUMova i načinu grupiranja.



**Slika 2.1:** Tijek procesa poravnavanja kod MUMmera 1.0

### **2.2.2. BLASTZ**

BLASTZ (Schwartz, et al., 2003) je alat koji omogućuje poravnanje dvaju genetskih nizova. Sastoji se od idućih faza: pronađak identičnih regija u genomima, proširenje identičnih regija, povezivanje proširenih regija, rekursivno ponavljanje prethodnog na regijama koje su ostale netaknute.

---

#### **Algoritam 1: BLASTZ**

---

1. Uklanjanje ponavljačih razasutih regija iz oba niza.
  2. Za sve dvanaestorke koje su identične ili se razlikuju u jednoj bazi u oba niza treba raditi iduće:
    - (a) Proširiti poravnanje oko pogotka u lijevo i desno, sve dok rezultat poravnjanja ne počne padati ispod zadanog praga.
    - (b) Ako je rezultantna ocjena poravnjanja veća od recimo 3000 tada:
      - i. Ponavljanje 2. koraka, tj. proširivati uz dozvoljavanje praznina.
      - ii. Ako je ocjena poravnjanja veća od recimo 5000 zabilježiti poravnanje.
  3. Između svaka dva para susjednih poravnanja iz koraka 2, ponoviti korak 2, ali uz korištenje senzitivnijih parametara (primjerice potraga za sedmorkama) i uz korištenje nižih pragova za poravnanje s i bez dozvoljenih praznina.
  4. Prilagoditi slijed pozicija rezultantnih regija poravnjanja tako da se mogu smjestiti u originalne nizove.
  5. Filtrirati rezultantne poravnate regije tako da se pronađe najbolji odgovarajući slijed.
- 

### **2.2.3. LASTZ**

LASTZ (Harris, 2007) podržava sve mogućnosti koje nudi i BLASTZ te ih još i proširuje. Pri tome pruža širi skup strategija obrade identičnih regija s kojima započinje proces poravnjanja te ima manju memoriju potrošnju. Bazira se na pretprocesiranju jednog genetskog slijeda, a zatim obavlja poravnanje nad drugim genetskim slijedom.

Memorijska poboljšanja ostvarena su na način što se prilikom obrade invertirajućih regija u memoriji ne drži zasebno reverzno komplementiran genetski slijed već su uvedene 4 dodatne funkcije (jedna za svaki smjer poravnjanja u oba niza) koje obrađuju regije u nizovima tako da je konačni rezultat isti. Međutim, takvo poboljšanje uzrokuje

teže održavanja koda.

Drugo memorijsko poboljšanje ostvareno je tako što su DNA nizovi pakirani po 4 baze u bajtu podataka umjesto prijašnjeg bajta po bazi. Također koristi i metode raspršenog adresiranja te dodatne strukture podataka koje iskorištavaju znatno manje memorije nego primjerice sufiksno stablo.

## 3. Podaci

Prilikom testiranja alata iz prethodnih poglavlja korišteni su genetski sljedovi koji se mogu preuzeti u FASTA formatu s poslužitelja Ensembl<sup>1</sup>. Moguće je preuzeti tekstualne zapise svih kromosoma čovjeka i brojnih ostalih životinjskih vrsta. FASTA format jednostavan je način zapisu, u prvom retku nalazi se opis a u svim ostalim redcima zapisan je genetski slijed. Genetski slijed sastoji se od pet znakova od kojih četiri označavaju dušične baze, a peti znak 'N' označava da nije poznato o kojoj se dušičnoj bazi radi (tablica 3.1).

Prilikom poravnjanja znak 'N' tretira se tako da se praktički ignorira u fazi prona-laska MUMova, dok je kod korištenja Smith-Watermana moguće tretirati znakove 'N' uz negativne cijene slično kao i praznine.

**Tablica 3.1:** Značenje znakova u genetskim sljedovima

Znak	Značenje
A	Adenin
C	Citozin
T	Timin
G	Gvanin
N	Nepoznato

Genetski sljedovi kromosoma čovjeka variraju po veličini ali okvirno su dugački po 150 milijuna dušičnih baza te takve datoteke zauzimaju i više od 100 MB memorijskog prostora.

Primjer FASTA datoteke<sup>2</sup> :

>9 dna:chromosome chromosome:GRCh37:9:1:141213431:1 REF

...NNNNNNNNNNNNNNNNNNNNNNNNNNNNNNNGAATTCCAGAACAC...

<sup>1</sup><http://www.ensembl.org/info/data/ftp/index.html>

<sup>2</sup>isječak iz 9. kromosoma, Homo sapiens

## 4. Metode

Rad programa opisanog u ovom radu bazira se na ideji alata MUMmer 1.0, a najznačajnija razlika je u tome što se koristi struktura podataka sufiksno polje koje bi uz efikasnu implementaciju trebalo koristiti mnogo manje memorije. Za ovu svrhu sufiksno polje nudi iste funkcionalnosti kao i sufiksno stablo te ga je moguće realizirati u linearnoj vremenskoj složenosti.

Alat radi s dva zadana niza, ali također generira reverzni komplement drugog zadalog niza te se paralelno obrađuju invertirajuće i neinvertirajuće regije. Za efikasno traženje MUMova koristi se sufiksno i LCP polje. Alatu je potrebno predati parametar koji predstavlja minimalnu duljinu koju MUMovi trebaju imati da bi se uzeli u obzir odnosno da bi bili dio rezultantnog poravnanja. Nakon toga iterativno se pronalaze MEMovi i MUMovi manje duljine od zadane na područjima između parova prethodno generiranih MUMova. Ovaj dio ključna je točka u procesu poravnanja te parametar kritične duljine bitno utječe kako na kvalitetu poravnanja tako i na trajanje izvođenja programa te memorijsku potrošnju.

Nakon generiranja MUMova i MEMova pojedina područja u ulaznim nizovima ostala su neporavnata te je nad njima potrebno provesti neki od dinamičkih algoritama poravnanja, konkretno Smith-Waterman algoritam (Smith and Waterman, 1981). Uz dobro određene parametre kritičnih duljina te ako se zadani nizovi podudaraju u određenom postotku Smith-Waterman algoritam bi se trebao izvršiti vrlo brzo jer će biti proveden nad regijama koje su znatno manjih duljina u odnosu na duljine početno zadanih nizova.

U konačnici se generira grafički prikaz rezultata poravnanja na kojem je moguće vizualno odrediti podudaranja, invertirajuće regije i translokacije pojedinih područja u genomu.

## 4.1. Konstrukcija SA i LCP polja

SA polje (*engl. Suffix Array*) je niz koji redom sadržava indekse sufiksa zadano niza u rastućem leksikografskom poretku. Postoje razne implementacije, ali u radu programa iskorištena je implementacija čija je vremenska složenost konstrukcije linearan<sup>1</sup>.

### Definicija:

Neka je zadan niz  $T$  duljine  $N$  gdje je  $T[i]$  sufiks koji započinje na indeksu  $i$  pri čemu je  $i \in [0, N - 1]$ .

Tada vrijedi:  $T[SA[i]] \leq T[SA[j]] \forall i, j \in [0, N - 1], i \leq j$

LCP polje (*engl. Longest Common Prefix*) dobije se vrlo lako nakon kreiranja SA polja te predstavlja temelj na kojem se zasniva funkcionalnost programa predstavljenog u ovom radu. Pojedini element LCP polja na nekom indeksu  $i$  predstavlja duljinu zajedničkog prefiksa od sufiksa na indeksu  $i$  te sufiksa na indeksu  $i - 1$ . Ako je  $LCP[i] = k$ , tada se  $T[SA[i]]$  i  $T[SA[i - 1]]$  podudaraju u prvih  $k$  znakova.

Prilikom konstrukcije sufiksnog polja za dva zadana niza potrebno je proslijediti konkatenaciju ulaznih nizova pri čemu se na kraj prvog niza prilijepi znak  $\$$  koji je leksikografski najmanje težine. Isti postupak potrebno je napraviti i s reverzno komplementiranim drugim nizom. Nakon ove procedure pripremljene su strukture podataka koje su potrebne u idućoj fazi pronalaska MUMova.

**Primjer:** Neka je zadan niz  $s_0 = \text{"banana\$"}$ .

**Tablica 4.1:** Sufiksno i LCP polje za niz "banana\$"

i	0	1	2	3	4	5	6
$s_0[i]$	b	a	n	a	n	a	\$
$SA[i]$	6	5	3	1	0	4	2

$s_0[SA[i]]$	\$	a	a	a	b	n	n
	\$	n	n	a	a	a	
		a	a	n	\$	n	
		\$	n	a		a	
			a	n		\$	
			\$	a			
				\$			
$LCP[i]$	0	0	1	3	0	0	2

<sup>1</sup><https://github.com/elventear/sais-lite-lcp>

## 4.2. Generiranje MUMova

Ovaj postupak se vrši u nekoliko iteracija kroz 3 dijela, a može se provesti tek kad su priređeni SA i LCP polje:

1. Pronalazak MUMova duljih od kritične duljine K, koristeći SA i LCP polje
2. Filtriranje MUMova pomoću LIS algoritma
3. Kreiranje novih SA i LCP polja za netaknute regije

Prvo obrađujemo cijelokupan niz, a zatim područja između parova MUMova. Iteriranje se radi dokle god to ima smisla, a u programu koji se opisuje ostavljena je mogućnost određivanja i tog parametra.

### 4.2.1. Pronalazak MUMova

Nakon priređenog SA i LCP polja može se započeti s fazom pronalaska MUMova koji su dulji od kritične duljine K. Sam postupak generiranja MUMova svodi se na prolaz kroz LCP polje i očitavanje elemenata LCP i SA polja. U nastavku slijedi algoritam:

---

#### Algoritam 2: Algoritam pronalaska MUMova pomoću SA i LCP polja

---

**Data:** Znakovni niz  $s_0$ , niz LCP, niz SA, K

**Result:** Lista MUMova

$i = 1;$

$N = \text{broj elemenata u LCP polju};$

**while**  $i < N - 1$  **do**

    | očitaj SA[i - 1], LCP[i], SA[i];

    | **if**  $T[SA[i]] \neq T[SA[i-1]]$  i  $T[SA[i-1]]$  sufksi istog niza **or**  $LCP[i] < K$  **then**  
    | | continue;

    | **else**

        | | **if**  $LCP[i] > LCP[i-1]$  **and**  $LCP[i] > LCP[i + 1]$  **then**

            | | | **if**  $T[SA[i] - 1] \neq T[SA[i-1] - 1]$  **then**

                | | | | dodajUListuMUMova(SA[i], SA[i - 1]);

---

Navedeni algoritam prolaskom kroz LCP polje traži sufikse koji se podudaraju u barem K početnih znakova te su nužno iz različitih početnih ulaznih nizova (tj. jedan sufiks treba biti na poziciji prije znaka \$, a drugi element tada treba biti na poziciji većoj od pozicije znaka \$). Isto tako treba biti zadovoljen uvjet maksimalnosti,

stoga se provjerava okolina elementa  $LCP[i]$ , a ako je taj uvjet (uvjet lokalnog maksimuma) zadovoljen tada još treba provjeriti da pronađeno poklapanje nije dio nekog većeg MUMa. Ako su znakovi na pozicijama neposredno prije pronađenih potencijalnih MUMova različiti tada MUM dodajemo u listu.

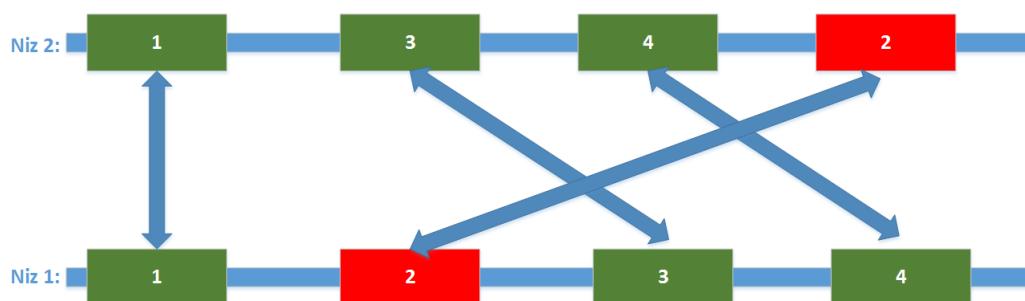
Važno je za uočiti da će broj pronađenih MUMova bitno ovisiti o parametru kritične duljine  $K$ . Ako je parametar  $K$  premalen tada će se stvoriti prevelik broj MUMova čije je postojanje rezultat puke slučajnosti (*engl. Noisy MUMs*). U slučaju prevelikog parametra  $K$  postoji mogućnost da će se pronaći premalo MUMova te se u idućoj iteraciji uz zadano smanjenje kritične duljine neće pronaći niti jedan novi MUM što će uzrokovati odmah prelazak na fazu poravnjanja netaknutih regija koje su u tom slučaju prevelike za Smith-Waterman algoritam.

Kritične duljine mogu varirati te ne ovise samo o veličini ulaznih nizova nad kojima se radi poravnanje, već i o međusobnoj sličnosti nizova.

#### 4.2.2. Filtriranje MUMova

MUMove koji su generirani u svakoj iteraciji prethodne faze potrebno je filtrirati i svrstati ih u sortiran poredak s obzirom na pozicije u prvom i drugom ulaznom nizu. To je nužno ako želimo jednoznačno odrediti područja rasprostiranja netaknutih regija i nad njima raditi daljnje iteracije.

Za početak sortiraju se MUMovi s obzirom na pozicije u referentnom nizu, a nakon toga eliminiraju se oni MUMovi čiji poredak nije u odgovarajućem redoslijedu. Ukratko rečeno primjenjuje se algoritam LIS (*engl. Largest Increasing Subsequence*) na MUMove s obzirom na pozicije u drugom nizu.



Slika 4.1: Primjena algoritma LIS

---

#### Algoritam 3: Filtriranje MUMova

---

**Data:** listaMUMova

**Result:** filtriranaListaMUMova

**i** = 1;

**N** = broj MUMova;

sortirajPoPozicijiX (listaMUMova);

**while**  $i < N$  **do**

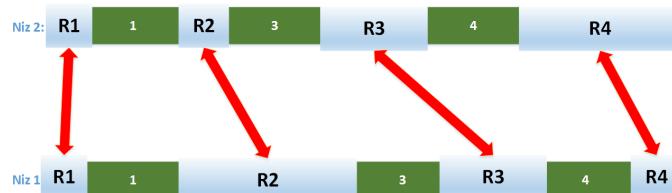
    | očitaj listaMUMova[i];

    | **if** listaMUMova[i].getPozicijaY() < listaMUMova[i - 1].getPozicijaY() **then**  
        | | listaMUMova[i].izbaci();

---

### 4.2.3. Generiranje listi LCP i SA polja za netaknute regije

Svaki uzastopni par generiranih MUMova razapinje po jednu netaknutu regiju u svakom od ulaznih nizova. Za svaku takvu regiju provodi se ekstrakcija elemenata polja SA koji joj pripadaju. Primjerice ako se raspolaže s N MUMova u općenitom slučaju postojat će  $N + 1$  takva regija (slika 4.2, označeno s Rx).



**Slika 4.2:** Netaknute regije za koje je potrebno kreirati zasebna LCP i SA polja

Kreiranje zasebnih LCP i SA polja za netaknute regije i nije toliko trivijalan postupak. Potrebno je kreirati nekoliko pomoćnih listi (jedna koja će pamtitи за svaku poziciju u konkateniranom nizu kojoj regiji pripada znak na toj poziciji te još  $2(N + 1)$  dodatna lista za svaku netaknuto regiju u koju će se pohraniti LCP i SA polja).

Problem generiranja novih SA polja može se riješiti prolaskom kroz početno SA polje tako da se za svaki element  $SA[i]$  ispita kojoj netaknutoj regiji pripada prvi znak sufiksa  $T[SA[i]]$  te se u pripadajuću listu umetne element  $SA[i]$ .

Generiranje novih LCP polja za navedene regije funkcioniра tako da se napravi prolaz po odgovarajućem SA polju pripadne regije i zatim se napravi upit koji odgovara na pitanje kolika je duljina zajedničkog prefiksa za  $SA[i-1]$  i  $SA[i]$ . Odgovor na to pitanje dobiva se u logaritamskoj složenosti koristeći segmentno stablo koje se samo jednom kreira na početku. Segmentno stablo vraća minimum na intervalu između LCP-ova koji se odnose na  $SA[i-1]$  i  $SA[i]$ .

---

#### Algoritam 4: Generiranje listi LCP i SA polja za netaknute regije

---

**Data:** SA, LCP, konkatenacija nizova T, netaknute regije REG

**Result:** listaLCPpolja, listaSAPolja

```

for  $\forall c \in T$  do
    označiPripadnostOdgovarajućojRegiji();
for  $\forall sa \in SA$  do
    listaSAPolja.dodaj(sa);
for  $\forall regija \in REG$  do
    for  $\forall sa \in regija.getSA()$  do
        minimum = segmentnoStablo.getMinimum(sa, sa.getOneBefore());
        listaLCPpolja.dodaj( minimum );
    
```

---

### 4.3. Smith-Waterman

Algoritam Smith-Waterman zasniva se na dinamičkom programiranju te pronalazi najbolje lokalno poravnanje za zadana dva niza, odnosno regije koje će imati najveći rezultat. U ovom programu koristi se kao završna faza u kojoj se poravnavaju netaknute regije.

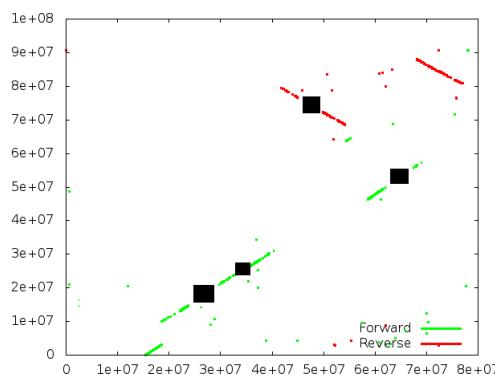
Smith-Waterman algoritam funkcioniра по sljedećoj formuli:

$$V(i, j) = \max \begin{cases} 0 & i = 0 \parallel j = 0 \\ \max \begin{cases} 0 \\ V(i - 1, j - 1) + w(s_i, t_j) & i > 0 \& j > 0 \\ V(i - 1, j) + d \\ V(i, j - 1) + d \end{cases} & \text{else} \end{cases}$$

Pri čemu je:

1.  $w(s_i, t_j)$  cijena zamjene
2.  $d$  je cijena umetanja ili brisanja
3.  $V$  je maksimalna vrijednost između podnizova  $s$  i  $t$  nad kojima se radi poravnanje na područjima  $s[1...i]$  i  $t[1...j]$

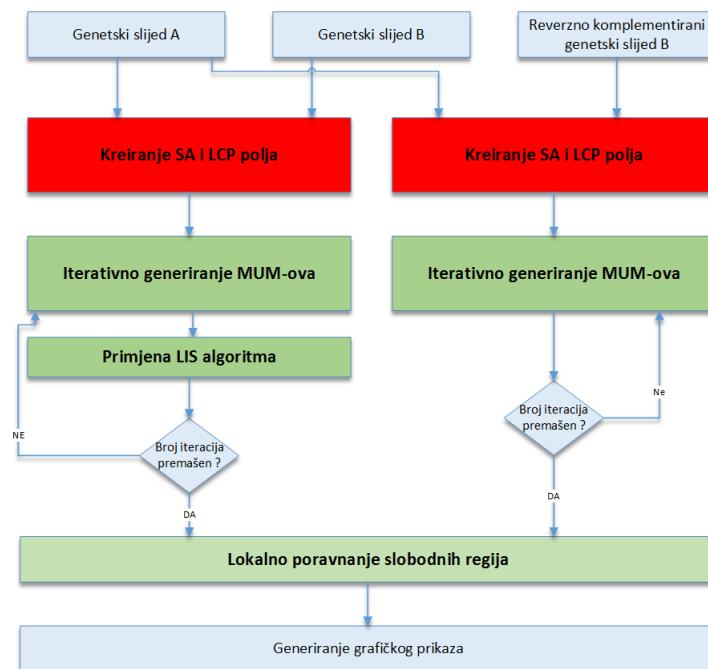
Na slici 4.3 prikazana su područja koja se trebaju poravnati koristeći Smith-Waterman algoritam. Zbog poprilične sličnosti genetskih nizova ta područja nisu pretjerano velika te će se poravnanje izvršiti relativno brzo.



**Slika 4.3:** Područja za poravnanje Smith-Watermanom

## 5. Implementacija

Alat koji je tema ovog rada napisan je u programskom jeziku C++ te je realiziran kao višedretveni program. Prilagođen je za izvođenje na Linux platformi. Prilikom pokretanja programa aktiviraju se dvije dretve koje paralelno generiraju sufiksno i LCP polje za normalne i reverzno komplementarne regije genoma. Nakon toga se paralelno izvode i generiraju MUMove te pri tome kreiraju još proizvoljan broj dretvi koje traže MUMove na netaknutim regijama prve iteracije, a zatim vrše Smith-Waterman algoritam. Izložena problematika s navedenim pristupom prirodno je takva da dretve mogu paralelno raditi na odvojenim dijelovima ulaznih nizova tako da nije bilo potrebe za sinkronizacijskim mehanizmima.



**Slika 5.1:** Dijagram toka opisanog programa

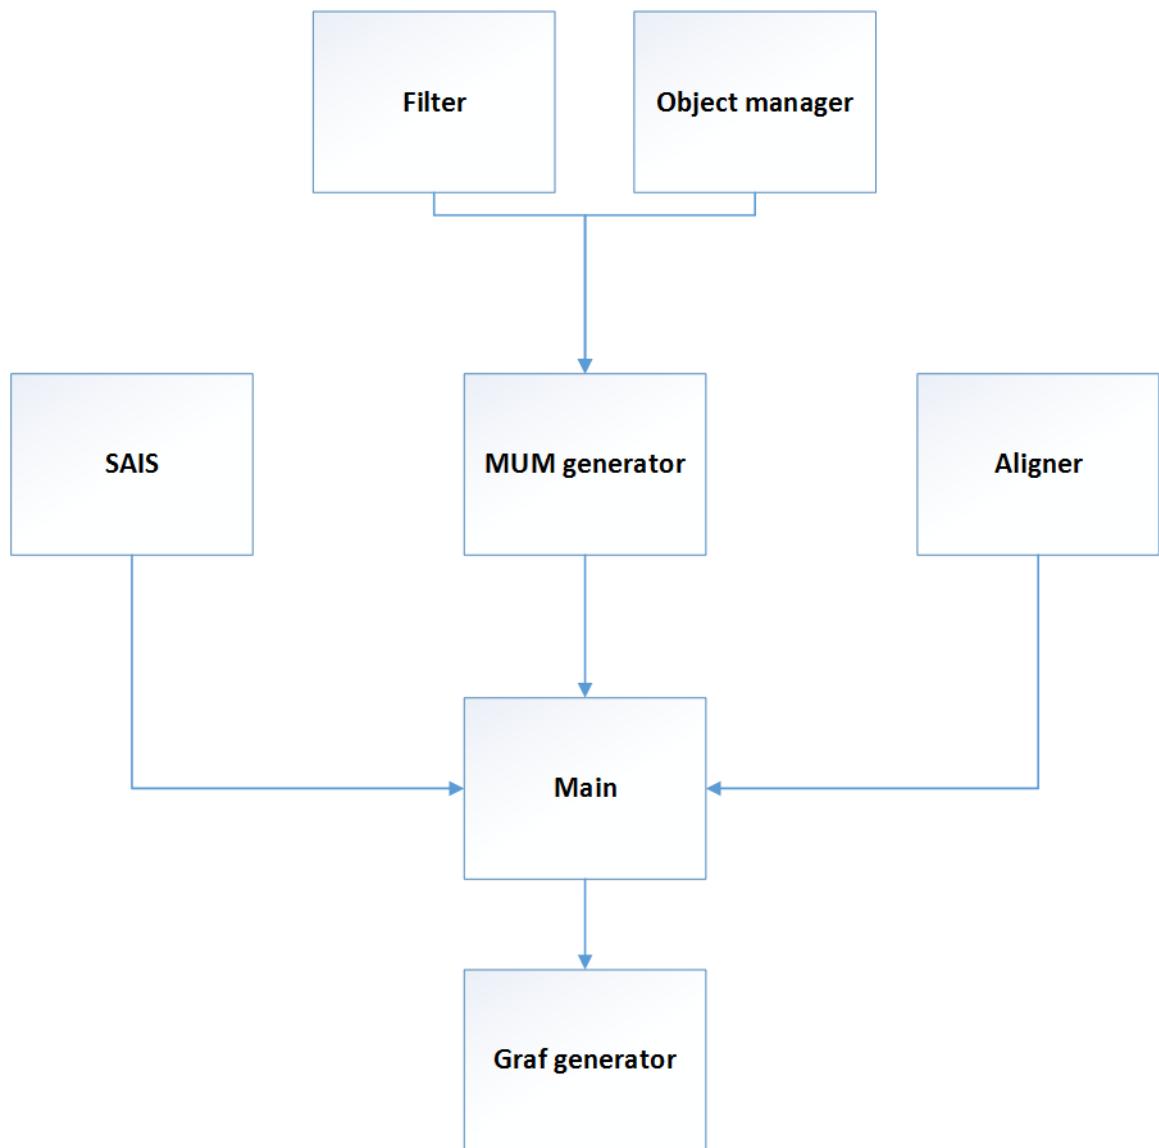
Crveno obojene dijelove na slici 5.1 obavljaju dvije dretve, a zeleno obojene dijelove proizvoljan broj dretvi. Međutim do lokalnog poravnjanja slobodnih regija dolazi se tek nakon što su izgenerirani svi MUMovi.

## 5.1. Arhitektura sustava

Sustav se može promatrati kao skup nekoliko modula. S obzirom na to da se problematika razlaže na nekoliko manjih komponenti bilo je prirodno rješavati pojedine probleme zasebno. U nastavku je dat i grafički prikaz arhitekture sustava pored tekstu-alnog opisa.

### Opis bitnih modula u sustavu:

1. **Main** - Glavni modul koji prima ulazne parametre te ih proslijedi ostalim modulima. Upravlja brojem dretvi te predstavlja pristupnu točku u sustav.
2. **SAIS** - Implementacija konstrukcije sufiksnog polja u linearnoj složenosti. Glavni modul mu predaje konkatenirane stringove, a kao rezultat dobiva SA i LCP polje.
3. **Aligner** - Kao parametre prima stringove i listu pozicija nad kojima treba izvršiti poravnanje. Kao rezultat vraća listu pozicija nad kojima je poravnanje izvršeno.
4. **MUM generator** - Za zadani konkatenaciju ulaznih nizova te SA i LCP polje vraća listu generiranih MUMova.
5. **Filter** - Kao parametre prima listu MUMova, a za rezultat vraća profiltrirane MUMove.
6. **Object manager** - Kreira segmentno stablo, liste LCP i SA polja vezane uz netaknute regije, sadrži sve bitne strukture podataka i njihove definicije.
7. **Graf generator** - Graf generator je modul koji od Main-a prima set točaka dužina koje treba iscrtati na grafu kao i ostale postavke grafa (izgled, boje, nazivi itd.). Koristi alat "gnuplot" za ispis grafa.



Slika 5.2: Arhitektura sustava

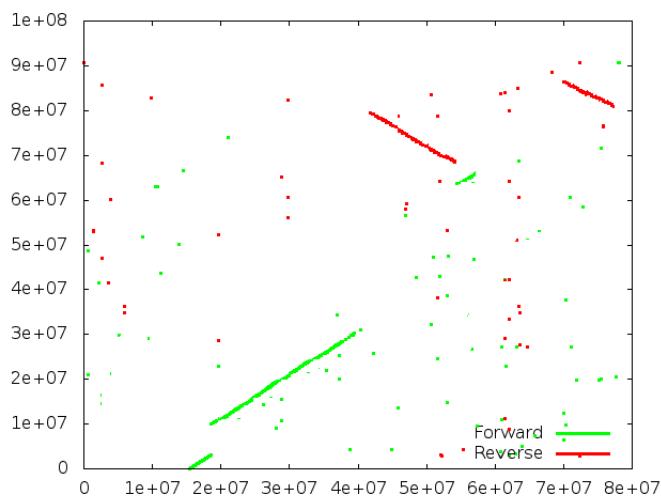
# 6. Rezultati

Prilikom testiranja alata poput MUMmera i alata opisanog u ovom radu korišteni su genetski sljedovi koji se mogu preuzeti s već navedenog Ensembl poslužitelja. Provedena su testiranja na kromosomima čovjeka i miša čije se duljine mjere u stotinu do dvije stotine milijuna dušičnih baza. Također su rezultati provjereni s onima na web stranici na kojoj su objavljena poravnanja za sve kromosome čovjeka s odgovarajućim kromosomima miša<sup>1</sup>. Sva testiranja obavljena su na serverskom računalu s 24 procesorske jezgre po 2.40GHz uz 200 GB radne memorije.

## 6.1. Ispitni skup

U nastavku su prikazani rezultati poravnjanja kromosoma čovjeka s kromosomom miša.

### "Miš/Čovjek - 18. kromosom"



Slika 6.1: Miš/Čovjek - 18. kromosom - kritična duljina 80

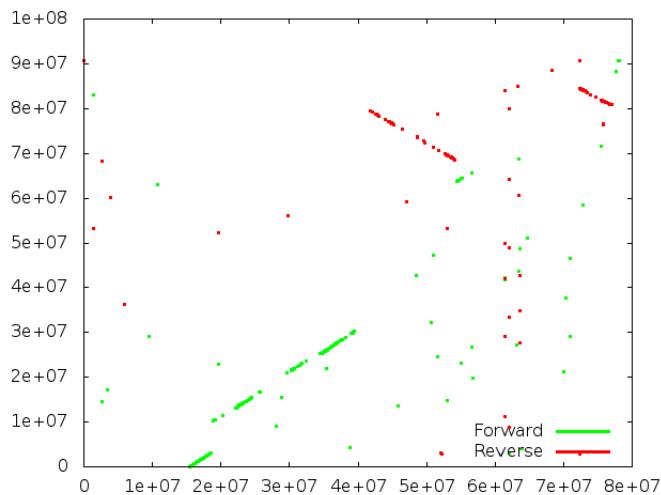
Zelenom linijom su prikazani dijelovi koji se poklapaju u genomima koji nisu reverzno komplementirani, dok crvene linije predstavljaju poklapanja referentnog niza

<sup>1</sup><http://www.broadinstitute.org/annotation/mouse/index.html>

s reverzno komplementiranim drugim nizom. Na slici se mogu primijetiti MUMovi šuma.

Mišji kromosom 18 je nešto kraće duljine nego čovjekov.

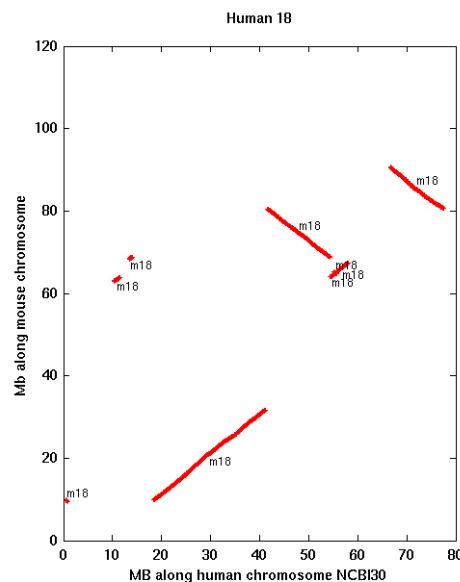
#### "Miš/Čovjek - 18. kromosom"



**Slika 6.2:** Miš/Čovjek - 18. kromosom - kritična duljina 120

Može se primijetiti smanjenje MUMova šuma prilikom korištenja znatno veće kritične duljine. Na slici 6.2 prikazan je rezultat pronađaka MUMova nakon prve iteracije.

#### "Miš/Čovjek - 18. kromosom - rezultati s Ensembl poslužitelja"



**Slika 6.3:** Miš/Čovjek - 18. kromosom - rezultati s Ensembl poslužitelja

**Tablica 6.1:** Konstrukcija SA i LCP polja

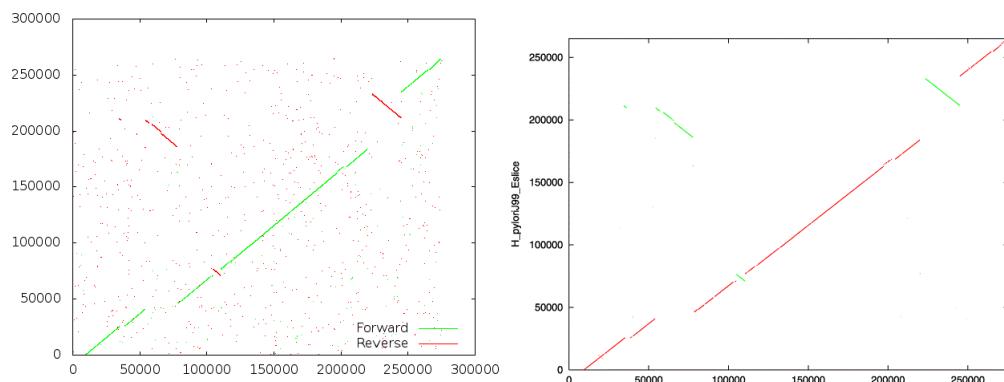
Podaci	Duljina konkanteniranih nizova	Memorija	Vrijeme
Čovjek Chr18 - Miš Chr18	168 779 888	4079 MB	203.15 s
H.pylori26695 H.pyloriJ99	540 399	< 3 MB	1.41 s
Čovjek Chr22 - Miš Chr15	155 348 252	2825 MB	170.16 s

**Tablica 6.2:** Iterativni pronađazak MUMova za 2 iteracije uz kritičnu duljinu 90

Podaci	Duljina konkanteniranih nizova	Memorija	Vrijeme
Čovjek Chr18 - Miš Chr18	168 779 888	15.1 GB	351.20 s
H.pylori26695 H.pyloriJ99	540 399	< 3 MB	0.30s
Čovjek Chr22 - Miš Chr15	155 348 252	13.8 GB	199.56s

## 6.2. Usporedba s alatom MUMmer

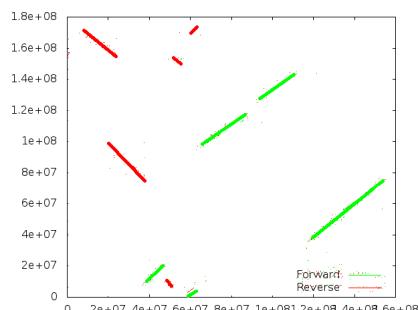
Alati su testirani na različitim test primjerima. Na primjerima koji su manji od 5M dušičnih baza gotovo da i nema neke značajnije razlike u performansama.



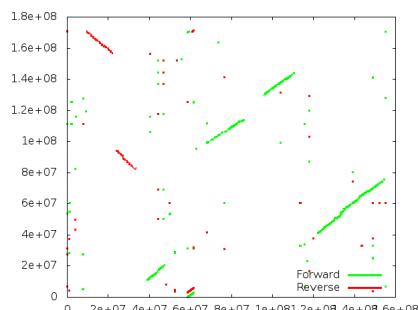
**Slika 6.4:** Usporedba: program opisan u radu (lijeva slika) - MUMmer (desna slika) za test primjer Hpylori

Na slici 6.4 vide se crvene točke koje predstavljaju reverzne MUMMove, rezultat je takav jer se nad reverznim regijama nije primjenio LIS algoritam, a početna kritična duljina je bila relativno mala.

### 6.2.1. Poravnanje kromosoma X Miš (173.9MB) / Čovjek (157.9MB):



Slika 6.5: Usporedba s MUMmerom - chrX - program opisan u radu



Slika 6.6: Usporedba s MUMmerom - chrX - MUMmer

1. **Vrijeme** - Vrijeme za cijelokupno poravnanje kod MUMmera za kromosom X iznosi 99 minuta, a rješenju iz rada treba 20 - 40 minuta ovisno o postavljenim parametrima.
2. **Memorija** - Za dani primjer konkatenacija nizova kromosoma čovjeka i miša zauzima 300MB. MUMmer koristi do 20GB memorije prilikom poravnanja, dok predloženo rješenje iskoristi 25GB. Prilikom konstrukcije sufiksnog stabla MUMmer zauzme 4,8GB dok alat iz rada pri konstrukciji sufiksnog polja za reverzno-komplementirani niz i običan zauzme 5,9GB.
3. **Točnost** - Rješenje opisano u radu poklapa se u prosjeku 90% s MUMmerom ovisno o namještenim parametrima nad skupom slučajnih podataka. Slučajevi u kojima rješenje iz rada "zakaže" su test primjeri u kojima je bio veći broj translatiranih regija koje je LIS algoritam jednostavno preskočio što je u konačnici uzrokovalo većim brojem praznina koje nisu mogle biti poravnate SW algoritmom. Ako se uzme u obzir set realnih podataka, dakle genetski zapisi koji su vrlo slični, opisano rješenje iz rada pronalazi sva značajna poklapanja.

## 7. Zaključak

Problematika ovog rada bila je poravnanje dvaju genetskih sljedova. Naglasak je bio na razvijanju efikasne metode pomoću koje će se dobiti što bolje i što preciznije rješenje u što kraćem vremenu. Pokazano je da algoritmi koji pronalaze optimalno rješenje nisu efikasni i mogu se koristiti samo na manjim skupovima podataka. Trenutačno najpopularniji alati baziraju se na heuristikama i velik broj ih radi po principu da odrede sjemena (*engl. seed*) koja predstavljaju čvrste fiksne točke za daljnji proces poravnjanja. Ideja koja stoji iza alata u ovom radu bila je riješiti problem slično kao i alat MUMmer, ali uz efikasnije memorijsko zauzeće korištenjem strukture sufiksno polje umjesto sufiksnog stabla te uz korištenje mehanizma paralelizacije. Pokazalo se da to vodi na dobar put, a paralelizirana verzija alata je za konstantu (broj aktivnih dretvi) brža od neparalelizirane verzije. U budućnosti je potrebno pokušati osmislti načine gdje i kako još poboljšati ovdje opisan alat. Neka od potencijalnih poboljšanja mogla bi biti osmišljavanje matematičkog modela po kojem će se procjenjivati ključni parametri, a uz to i implementacija algoritma za grupiranje MUMova. Trenutno korišteni algoritam LIS za filtriranje uklanjanja regije koje su translatirane, ali bi one ipak trebale biti prikazane ako nisu rezultat slučajnosti i ako je njihova ukupna duljina značajna. MUMmer 3.0 rješava problem grupiranja i uzima u obzir translatirane regije zbog čega je vrijeme njegovog izvođenja nešto veće, ali je time i točnost veća.

# LITERATURA

- [1] Dan Gusfield. *Algorithms on Strings, Trees, and Sequences Computer Science and Computational Biology*. Cambridge University Press, 1997.
- [2] Ge Nong, Sen Zhang, and Wai Hong Chan. *Two Efficient Algorithms for Linear Time Suffix Array Construction*. 1999.
- [3] Scott Schwartz, W. James Kent, Arian Smit, Zheng Zhang, Robert Baertsch, Ross C. Hardison, David Haussler, Webb Miller. *Human–Mouse Alignments with BLASTZ*. 2003.
- [4] Robert S. Harris. *IMPROVED PAIRWISE ALIGNMENT OF GENOMIC DNA*. 2007.
- [5] Neil C Jones i Pavel Pevzner. *An introduction to bioinformatics algorithms*. MIT press, 2004.
- [6] Matija Korpar. Implementacija smith waterman algoritma koristeći grafičke kartice s cuda arhitekturom. 2011.
- [7] Mile Šikić i Mirjana Domazet-Lošo. *Bioinformatika*. 2013.
- [8] L Deicher, Kasif, D. Fleischmann, Peterson, White, L. Salzberg. *Alignment of whole genomes*. 1997.

## **Alat za poravnanje genoma**

### **Sažetak**

Poravnanje genoma je jedan od većih problema u bioinformatici koji još uvijek nije efikasno riješen. Iako su poznati egzaktni algoritmi kojima bi se moglo doći do optimalnog rješenja, oni se ipak ne koriste jer bi njihovo izvođenje zahtjevalo previše vremena.

U radu je opisan alat za poravnanje genoma ostvaren kao višedretveni program u programskom jeziku C++. Alat se bazira na pronašlaku identičnih podnizova zadanih genoma pomoću sufiksнog polja, a nakon toga na primjeni algoritma Smith-Waterman na područja u kojima nisu pronađeni MUMovi. Konačan rezultat je grafički prikaz koji prikazuje identične, translatirane i reverzno komplementirane regije u zadanim genomima.

**Ključne riječi:** Poravnanje, genom, sufiksno polje, paralelizacija, heuristika, bioinformatica

### **Title**

### **Abstract**

Genome alignment is one of the major problems in bioinformatics that still have not been effectively resolved. Although exact algorithms which would give optimal solution are known, they are not used because of their long running time.

In this thesis is described tool for genome alignment realized like multithreaded application written in C++. Tool is based on locating identical interval regions in given genomes by using suffix array, and after that by using Smith-Waterman algorithm on regions in which MUMs were not found. Final result is graphical representation of identical, translocated and reverse complemented regions in given genomes.

**Keywords:** Alignment, genome, suffix array, parallelization, heuristics, bioinformatics